



(19) 대한민국특허청(KR)  
(12) 공개특허공보(A)

(11) 공개번호 10-2021-0035530  
(43) 공개일자 2021년04월01일

(51) 국제특허분류(Int. Cl.)  
G06N 3/08 (2006.01) G06N 3/04 (2006.01)  
(52) CPC특허분류  
G06N 3/082 (2013.01)  
G06N 3/0427 (2013.01)  
(21) 출원번호 10-2019-0117432  
(22) 출원일자 2019년09월24일  
심사청구일자 2019년09월24일

(71) 출원인  
연세대학교 산학협력단  
서울특별시 서대문구 연세로 50 (신촌동, 연세대학교)  
(72) 발명자  
이중석  
인천광역시 남동구 소래역로 93  
장수범  
인천광역시 연수구 송도과학로 85  
(74) 대리인  
김권석

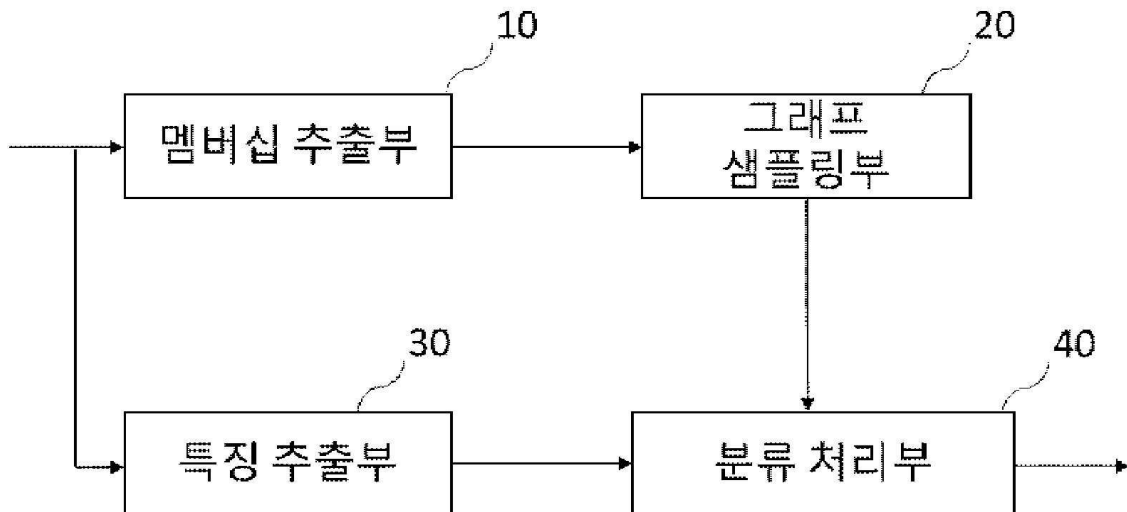
전체 청구항 수 : 총 16 항

(54) 발명의 명칭 연결성 학습 장치 및 연결성 학습 방법

(57) 요약

본 발명의 일 실시예에 따른 연결성 학습 장치는, 심층 신경망 학습에 의해 복수의 객체들 간의 연결성을 판단하고, 판단된 연결성에 기초하여 입력 신호를 분류하기 위한 연결성 학습 장치로서, 상기 복수의 객체들로부터 얻어진 원시 신호로부터 상기 객체들 간의 연결성의 존재를 나타내는 멤버십을 추출하는 멤버십 추출부; 추출된 멤버십으로부터 상기 객체들 간의 연결성을 샘플링하여 상기 객체들 간의 연결성을 그래프로 표현하는 그래프 구조를 생성하는 그래프 샘플링부; 상기 원시 신호로부터 신호 특징을 추출하는 특징 추출부; 및 생성된 상기 그래프 구조 및 추출된 상기 신호 특징에 기초하여 입력 신호를 복수의 클래스 중 어느 하나로 분류하는 분류 처리부를 포함할 수 있다.

대표도 - 도1



이 발명을 지원한 국가연구개발사업

|             |  |
|-------------|--|
| 과제고유번호      | 1711116255                                   |
| 과제번호        | 2016-0-00564-005                             |
| 부처명         | 과학기술정보통신부                                    |
| 과제관리(전문)기관명 | 정보통신기획평가원(한국연구재단부설)                          |
| 연구사업명       | 정보통신방송연구개발사업                                 |
| 연구과제명       | [통합이지바로][주관/경북대학교] 사용자의의도와 맥락을 이해하는 지능형 인터랙션 |
| 기술연구개발(5/5) |  |
| 기 여 율       | 1/1  |
| 과제수행기관명     | 경북대학교산학협력단                                   |
| 연구기간        | 2020.03.01 ~ 2020.12.31                      |

---

## 명세서

### 청구범위

#### 청구항 1

심층 신경망 학습에 의해 복수의 객체들 간의 연결성을 판단하고, 판단된 연결성에 기초하여 입력 신호를 분류하기 위한 연결성 학습 장치로서,

상기 복수의 객체들로부터 얻어진 원시 신호로부터 상기 객체들 간의 연결성의 존재를 나타내는 멤버십을 추출하는 멤버십 추출부;

추출된 멤버십으로부터 상기 객체들 간의 연결성을 샘플링하여 상기 객체들 간의 연결성을 그래프로 표현하는 그래프 구조를 생성하는 그래프 샘플링부;

상기 원시 신호로부터 신호 특징을 추출하는 특징 추출부; 및

생성된 상기 그래프 구조 및 추출된 상기 신호 특징에 기초하여 입력 신호를 복수의 클래스 중 어느 하나로 분류하는 분류 처리부

를 포함하는 연결성 학습 장치.

#### 청구항 2

제 1 항에 있어서,

상기 객체들 간의 연결성은 2 이상의 타입을 갖는 연결성 학습 장치.

#### 청구항 3

제 2 항에 있어서,

상기 멤버십 추출부는 상이한 타입의 연결성을 나타내는 2 이상의 연결성 레이어에 대하여 상기 멤버십을 추출하는 연결성 학습 장치.

#### 청구항 4

제 3 항에 있어서,

상기 그래프 샘플링부는 각 연결성 레이어에 대하여 하나의 그래프 레이어를 생성하고, 상기 그래프 구조는 2 이상의 그래프 레이어를 포함하는 연결성 학습 장치.

#### 청구항 5

제 4 항에 있어서,

상기 그래프 샘플링부는, 추출된 상기 멤버십이 나타내는 값이 임계값 이상인지 여부에 기초하여 상기 객체들 간의 연결성을 샘플링하는 결정론적 이진화에 의해 상기 그래프 구조를 생성하는 연결성 학습 장치.

#### 청구항 6

제 1 항에 있어서,

상기 원시 신호 또는 상기 입력 신호는 복수의 센서로부터 취득된 기능적 자기공명영상(Functional Magnetic Resonance Imaging, fMRI), 뇌전도(electroencephalography, EEG) 및 기능적 근적외선 분광(Functional Near Infrared Spectroscopy, fNIRS) 중 하나 이상을 포함하는 연결성 학습 장치.

#### 청구항 7

제 1 항에 있어서,

상기 특징 추출부는 컨벌루션 연산 및 맥스 풀링 연산에 의해 상기 원시 신호로부터 신호 특징을 추출하는 연결

성 학습 장치.

#### 청구항 8

제 7 항에 있어서,

상기 컨벌루션 연산은 복수의 시간 간격을 갖는 확장된 컨벌루션 레이어를 이용하여 수행되는 연결성 학습 장치.

#### 청구항 9

심층 신경망 학습에 의해 복수의 객체들 간의 연결성을 판단하고, 판단된 연결성에 기초하여 입력 신호를 분류하기 위한 연결성 학습 방법으로서,

상기 복수의 객체들로부터 얻어진 원시 신호로부터 상기 객체들 간의 연결성의 존재를 나타내는 멤버십을 추출하는 멤버십 추출 단계;

추출된 멤버십으로부터 상기 객체들 간의 연결성을 샘플링하여 상기 객체들 간의 연결성을 그래프로 표현하는 그래프 구조를 생성하는 그래프 샘플링 단계;

상기 원시 신호로부터 신호 특징을 추출하는 특징 추출 단계; 및

생성된 상기 그래프 구조 및 추출된 상기 신호 특징에 기초하여 상기 입력 신호를 복수의 클래스 중 어느 하나로 분류하는 분류 처리 단계

를 포함하는 연결성 학습 방법.

#### 청구항 10

제 9 항에 있어서,

상기 객체들 간의 연결성은 2 이상의 타입을 갖는 연결성 학습 방법.

#### 청구항 11

제 10 항에 있어서,

상기 멤버십 추출 단계에서는 상이한 타입의 연결성을 나타내는 2 이상의 연결성 레이어에 대하여 상기 멤버십이 추출되는 연결성 학습 방법.

#### 청구항 12

제 11 항에 있어서,

상기 그래프 샘플링 단계에서는 각 연결성 레이어에 대하여 하나의 그래프 레이어가 생성되고, 상기 그래프 구조는 2 이상의 그래프 레이어를 포함하는 연결성 학습 방법.

#### 청구항 13

제 12 항에 있어서,

상기 그래프 샘플링 단계는, 추출된 상기 멤버십이 나타내는 값이 임계값 이상인지 여부에 기초하여 상기 객체들 간의 연결성을 샘플링하는 결정론적 이진화에 의해 상기 그래프 구조를 생성하는 연결성 학습 방법.

#### 청구항 14

제 9 항에 있어서,

상기 원시 신호 또는 상기 입력 신호는 복수의 센서로부터 취득된 기능적 자기공명영상(Functional Magnetic Resonance Imaging, fMRI), 뇌전도(electroencephalography, EEG) 및 기능적 근적외선 분광(Functional Near Infrared Spectroscopy, fNIRS) 중 하나 이상을 포함하는 연결성 학습 방법.

#### 청구항 15

제 9 항에 있어서,

상기 특징 추출 단계에서는 컨벌루션 연산 및 맥스 풀링 연산에 의해 상기 원시 신호로부터 신호 특징이 추출되는 연결성 학습 방법.

## 청구항 16

제 15 항에 있어서,

상기 컨벌루션 연산은 복수의 시간 간격을 갖는 확장된 컨벌루션 레이어를 이용하여 수행되는 연결성 학습 방법.

## 발명의 설명

### 기술 분야

[0001] 본 발명은 연결성 학습에 관한 것으로서, 더욱 상세하게는, 복수의 객체간의 연결성을 학습하기 위한 연결성 학습 장치 및 연결성 학습 방법에 관한 것이다.

### 배경 기술

[0002] 뇌전도(EEG:electroencephalography)와 같은 뇌 영상을 통한 뇌 활동 분석은 인간의 정신 상태나 생각을 이해하는데 중요하다. 이러한 뇌 활동 분석은 뇌와 컴퓨터 간의 인터페이스, 감정 인식 및 정신 질환 진단을 포함한 다양한 응용 분야에서 필수적이다. 뇌는 여러 기능 영역으로 구성되며, 여러 기능 영역에 걸친 활성화 패턴은 정신 상태에 관한 가치 있는 정보를 제공한다. 따라서, 기능적 연결성(본 명세서에서는 간략화를 위해 '연결성'이라고도 함)이라고 하는 패턴으로 나타나는 영역간 관계를 연구하는 것이 뇌 신호 분석에 효과적이다. 뇌 영역은 유클리드 공간에 있지 않기 때문에 그래프는 연결성을 나타내는 가장 자연스럽고 적합한 데이터 구조이다.

[0003] 그러나, 연결성의 정도를 측정하는 방법, 적절한 그래프 구조를 정의하는 방법 및 다른 뇌 영역으로부터의 신호에 대한 적절한 기능을 정의하는 방법은 여전히 해결되지 않은 문제이다. 이러한 문제들은 일반적으로 사전 지식에 따라 수동으로 결정된다. 예를 들어, 서로 다른 영역의 신호 사이의 상관 또는 인과 관계 행렬은 연결성 측정치로 사용될 수 있다. 그리고, 높은 연결성 값을 나타내는 뇌 영역 쌍을 연결함으로써 그래프를 구성할 수 있고, 마지막으로, 신호의 파워 또는 엔트로피가 각 영역의 특징(즉, 그래프의 정점)으로서 사용될 수 있다. 그러나 이러한 문제를 수동으로 해결하는 것이 최선의 방법은 아니다. 실제로 이러한 문제는 뇌 신호 데이터뿐만 아니라 소셜 네트워크 및 화학 물질과 같은 그래프 구조와 관련된 기타 데이터에도 동일하게 적용된다.

## 발명의 내용

### 해결하려는 과제

[0004] 본 발명이 해결하고자 하는 과제는 사전 지식이 전혀 없는 상태에서도 원시 신호에 기초한 직접 학습을 통해 향상된 정확도로 신호 분류를 수행할 수 있는 연결성 학습 장치를 제공하는 것이다.

[0005] 본 발명이 해결하고자 하는 다른 과제는 하나의 객체 쌍 사이의 연결성이 아닌 복수의 객체들 사이에 상호 연결성을 갖는 네트워크의 전체 상태를 표현할 수 있는 연결성 학습 장치를 제공하는 것이다.

[0006] 본 발명이 해결하고자 하는 또 다른 과제는 복수의 객체들 사이에 상호 연결성이 얼마나 존재하는지에 대한 정보, 즉 그래프 구조에 대한 명시적인 손실 함수가 주어지지 않은 경우에도 복수의 객체들 사이의 연결성을 판정할 수 있는 연결성 학습 장치를 제공하는 것이다.

[0007] 본 발명이 해결하고자 하는 또 다른 과제는 상기 연결성 학습 장치에 의해 수행되는 연결성 학습 방법을 제공하는 것이다.

### 과제의 해결 수단

[0008] 상기 과제를 해결하기 위한 본 발명의 일 실시예에 따른 연결성 학습 장치는, 심층 신경망 학습에 의해 복수의 객체들 간의 연결성을 판단하고, 판단된 연결성에 기초하여 입력 신호를 분류하기 위한 연결성 학습 장치로서, 상기 복수의 객체들로부터 얻어진 원시 신호로부터 상기 객체들 간의 연결성의 존재를 나타내는 멤버십을 추출

하는 멤버십 추출부; 추출된 멤버십으로부터 상기 객체들 간의 연결성을 샘플링하여 상기 객체들 간의 연결성을 그래프로 표현하는 그래프 구조를 생성하는 그래프 샘플링부; 상기 원시 신호로부터 신호 특징을 추출하는 특징 추출부; 및 생성된 상기 그래프 구조 및 추출된 상기 신호 특징에 기초하여 입력 신호를 복수의 클래스 중 어느 하나로 분류하는 분류 처리부를 포함할 수 있다.

[0009] 일 실시예에서, 상기 객체들 간의 연결성은 2 이상의 타입을 가질 수 있다. 또한, 상기 멤버십 추출부는 상이한 타입의 연결성을 나타내는 2 이상의 연결성 레이어에 대하여 상기 멤버십을 추출할 수 있다.

[0010] 일 실시예에서, 상기 그래프 샘플링부는 각 연결성 레이어에 대하여 하나의 그래프 레이어를 생성하고, 상기 그래프 구조는 2 이상의 그래프 레이어를 포함할 수 있다. 또한, 상기 그래프 샘플링부는, 추출된 상기 멤버십이 나타내는 값이 임계값 이상인지 여부에 기초하여 상기 객체들 간의 연결성을 샘플링하는 결정론적 이진화에 의해 상기 그래프 구조를 생성할 수 있다.

[0011] 일 실시예에서, 상기 원시 신호 또는 상기 입력 신호는 복수의 센서로부터 취득된 기능적 자기공명영상(Functional Magnetic Resonance Imaging, fMRI), 뇌전도(electroencephalography, EEG) 및 기능적 근적외선 분광(Functional Near Infrared Spectroscopy, fNIRS) 중 하나 이상을 포함할 수 있다.

[0012] 일 실시예에서, 상기 특징 추출부는 컨벌루션 연산 및 맥스 풀링 연산에 의해 상기 원시 신호로부터 신호 특징을 추출할 수 있다. 또한, 상기 컨벌루션 연산은 복수의 시간 간격을 갖는 확장된 컨벌루션 레이어를 이용하여 수행될 수 있다.

[0013] 상기 과제를 해결하기 위한 본 발명의 다른 실시예에 따른 연결성 학습 방법은, 심층 신경망 학습에 의해 복수의 객체들 간의 연결성을 판단하고, 판단된 연결성에 기초하여 입력 신호를 분류하기 위한 연결성 학습 방법으로서, 상기 복수의 객체들로부터 얻어진 원시 신호로부터 상기 객체들 간의 연결성의 존재를 나타내는 멤버십을 추출하는 멤버십 추출 단계; 추출된 멤버십으로부터 상기 객체들 간의 연결성을 샘플링하여 상기 객체들 간의 연결성을 그래프로 표현하는 그래프 구조를 생성하는 그래프 샘플링 단계; 상기 원시 신호로부터 신호 특징을 추출하는 특징 추출 단계; 및 생성된 상기 그래프 구조 및 추출된 상기 신호 특징에 기초하여 상기 입력 신호를 복수의 클래스 중 어느 하나로 분류하는 분류 처리 단계를 포함할 수 있다.

[0014] 일 실시예에서, 상기 객체들 간의 연결성은 2 이상의 타입을 가질 수 있다. 또한, 상기 멤버십 추출 단계에서는 상이한 타입의 연결성을 나타내는 2 이상의 연결성 레이어에 대하여 상기 멤버십이 추출될 수 있다.

[0015] 일 실시예에서, 상기 그래프 샘플링 단계에서는 각 연결성 레이어에 대하여 하나의 그래프 레이어가 생성되고, 상기 그래프 구조는 2 이상의 그래프 레이어를 포함할 수 있다. 또한, 상기 그래프 샘플링 단계는, 추출된 상기 멤버십이 나타내는 값이 임계값 이상인지 여부에 기초하여 상기 객체들 간의 연결성을 샘플링하는 결정론적 이진화에 의해 상기 그래프 구조를 생성할 수 있다.

[0016] 일 실시예에서, 상기 원시 신호 또는 상기 입력 신호는 복수의 센서로부터 취득된 기능적 자기공명영상(Functional Magnetic Resonance Imaging, fMRI), 뇌전도(electroencephalography, EEG) 및 기능적 근적외선 분광(Functional Near Infrared Spectroscopy, fNIRS) 중 하나 이상을 포함할 수 있다.

[0017] 일 실시예에서, 상기 특징 추출 단계에서는 컨벌루션 연산 및 맥스 풀링 연산에 의해 상기 원시 신호로부터 신호 특징이 추출될 수 있다. 또한, 상기 컨벌루션 연산은 복수의 시간 간격을 갖는 확장된 컨벌루션 레이어를 이용하여 수행될 수 있다.

## 발명의 효과

[0018] 본 발명의 실시예에 따르면, 복수의 객체들 간의 복수의 연결성을 나타내는 그래프 구조 및 신호 특징을 자동적으로 추출하고, 추출된 그래프 구조와 신호 특징을 이용하여 신호 분류를 수행하는 새로운 심층 학습 모델을 이용함으로써, 사전 지식이 전혀 없는 상태에서도 원시 신호에 기초한 직접 학습을 통해 향상된 정확도로 신호 분류를 수행할 수 있고, 복수의 객체들 사이에 상호 연결성을 갖는 네트워크의 전체 상태를 표현할 수 있으며, 손실 함수가 주어지지 않은 경우에도 복수의 객체들 사이의 연결성을 판정할 수 있는 연결성 학습 장치 및 연결성 학습 방법이 제공될 수 있다.

## 도면의 간단한 설명

[0019] 도 1은 본 발명의 일 실시예에 따른 연결성 학습 장치의 블록도이다.

도 2는 본 발명의 일 실시예에 따른 멤버십 추출부(10)의 구성을 도시하는 개념도이다.

도 3은 본 발명의 일 실시예에 따른 그래프 샘플링부(20)의 구성을 도시하는 개념도이다.

도 4는 본 발명의 일 실시예에 따른 특징 추출부(30)의 구성을 도시하는 개념도이다.

도 5는 본 발명의 일 실시예에 따른 분류 처리부(40)의 구성을 도시하는 개념도이다.

도 6a 내지 도 6d는 본 발명의 일 실시예에 따른 원시 신호 및 추출된 그래프를 도시한다.

도 7은 본 발명에서 사용된 그래프 표현을 위한 32개의 EEG 전극의 명칭 및 위치를 도시하는 그래프이다.

도 8a 내지 도 8c는 본 발명의 일 실시예에 따라 얻어진 그래프 구조의 예를 도시하는 그래프이다.

도 9는 본 발명의 일 실시예에 따른 연결성 학습 방법을 나타내는 흐름도이다.

### 발명을 실시하기 위한 구체적인 내용

[0020]

이하, 첨부된 도면을 참조하여 본 발명의 바람직한 실시예를 상세히 설명하기로 한다.

[0021]

본 발명의 실시예들은 당해 기술 분야에서 통상의 지식을 가진 자에게 본 발명을 더욱 완전하게 설명하기 위하여 제공되는 것이며, 하기 실시예는 여러 가지 다른 형태로 변형될 수 있으며, 본 발명의 범위가 하기 실시예에 한정되는 것은 아니다. 오히려, 이들 실시예는 본 개시를 더욱 충실하고 완전하게 하고, 당업자에게 본 발명의 사상을 완전하게 전달하기 위하여 제공되는 것이다.

[0022]

이하, 본 발명의 실시예들은 본 발명의 이상적인 실시예들을 개략적으로 도시하는 도면들을 참조하여 설명된다. 도면들에 있어서, 예를 들면, 부재들의 크기와 형상은 설명의 편의와 명확성을 위하여 과장될 수 있으며, 실제 구현시, 도시된 형상의 변형들이 예상될 수 있다. 따라서, 본 발명의 실시예는 본 명세서에 도시된 부재 또는 영역의 특정 형상에 제한된 것으로 해석되어서는 아니 된다.

[0024]

본 발명은 딥 러닝 모델에 의해 생성된 연결성 구조를 이용하여 주어진 신호 데이터의 분류를 수행하는 신경망 모델을 구축할 수 있다. 주어진 데이터는  $(X, y)$ 로 표현되며, 여기서  $X \in \mathbb{R}^{N \times T}$  이고,  $X$  는 N 개의 센서 (일 실시예에서 EEG 전극)로부터 수집된 시계열 신호 세트이고,  $y$ 는 대응하는 클래스 레이블이다.

[0025]

추정되는 그래프 구조는 자가 루프가 없는 가중치 및 방향성을 갖는 멀티 레이어 그래프이고, 그래프 구조(G)는 수학적 식 1로 표현될 수 있다.

[0026]

$$G = (V, \{E^k\}_{k=1}^K, \{W^k\}_{k=1}^K) \quad (\text{수학적 식 1})$$

[0027]

정점(vertex)을 나타내는 V는 수학적 식 2로 표현될 수 있고, 간선(edge)의 존재를 나타내는 E는 수학적 식 3으로 표현될 수 있고, 가중치를 나타내는 W는 수학적 식 4로 표현될 수 있다.

[0028]

$$V = \{v_i\}_{i=1}^N \quad (\text{수학적 식 2})$$

[0029]

$$E^k \in \{0, 1\}^{N^2} \quad (\text{수학적 식 3})$$

[0030]

$$W^k = \{w_{ij}^k\}_{i,j=1}^N \in \mathbb{R}^{N \times N} \quad (\text{수학적 식 4})$$

[0031]

$E^k$ 는 k번째 그래프 레이어에서 정점 쌍 사이의 간선의 존재를 나타내고,  $W^k$ 는 정점 쌍 사이의 간선 가중치를 나타낸다.  $w_{ij}^k \in [0, 1]$  로 가정되었고, K는 그래프 레이어의 개수를 제어하는 하이퍼 파라미터이다.



- [0033] 도 1은 본 발명의 일 실시예에 따른 연결성 학습 장치(1)의 블록도이다.
- [0034] 도 1을 참조하면, 연결성 학습 장치(1)는 멤버십 추출부(10), 그래프 샘플링부(20), 특징 추출부(30) 및 분류 처리부(40)를 포함할 수 있다. 연결성 학습 장치(1)는 심층 신경망 학습에 의해 복수의 객체들 간의 연결성을 판단하고, 판단된 연결성에 기초하여 입력 신호를 분류할 수 있다.
- [0035] 객체들 간의 연결성은 인과 관계 또는 상관 관계를 포함하고, 2 이상의 타입을 포함할 수 있다. 객체들 간의 연결성이 2 이상의 타입을 포함하는 경우에는 후술하는 바와 같이 복수의 연결성 레이어에 의해 표현될 수 있다.
- [0036] 멤버십 추출부(10)는 복수의 객체들로부터 얻어진 원시 신호로부터 객체들 간의 연결성의 존재를 나타내는 멤버십을 추출하고, 추출된 멤버십을 그래프 샘플링부(20)로 출력할 수 있다. 일 실시예에서, 객체는 다양한 신호를 센싱 또는 감지할 수 있는 센서 또는 감지 소자를 포함할 수 있다.
- [0037] 원시 신호 또는 입력 신호는 기능적 자기공명영상(Functional Magnetic Resonance Imaging, fMRI), 뇌전도(electroencephalography, EEG) 및 기능적 근적외선 분광(Functional Near Infrared Spectroscopy, fNIRS) 중 하나 이상을 포함할 수 있다. 원시 신호 또는 입력 신호는 뇌와 관련된 신호에 한정되지 않고, 다른 실시예에서는 심장과 관련된 영상 또는 음향 신호를 포함할 수도 있다. 다른 실시예에서, 원시 신호 또는 입력 신호는 풍량 또는 풍속과 같은 기상 데이터에 관한 신호나 도로의 차량 통행을 나타내는 영상 신호를 포함할 수 있다.
- [0038] 객체들 간의 연결성이 2 이상의 타입인 경우에, 멤버십 추출부(10)는 상이한 타입의 연결성을 나타내는 2 이상의 연결성 레이어 각각에 대하여 멤버십을 추출할 수 있다. 또한, 이러한 경우에, 그래프 샘플링부(20)는 각 연결성 레이어에 대하여 하나의 그래프 레이어를 생성할 수 있다.
- [0039] 그래프 샘플링부(20)는 멤버십 추출부(10)에 의해 추출된 멤버십으로부터 객체들 간의 연결성을 샘플링하여 객체들 간의 연결성을 그래프로 표현하는 그래프 구조를 생성하고, 생성된 그래프 구조를 분류 처리부(40)로 출력할 수 있다.
- [0040] 또한, 그래프 샘플링부(20)는 멤버십 추출부(10)에 의해 추출된 멤버십이 나타내는 값이 임계값 이상인지 여부에 기초하여 객체들 간의 연결성을 샘플링하는 결정론적 이진화에 의해 그래프 구조를 생성할 수 있다.
- [0041] 특징 추출부(30)는 복수의 객체들로부터 얻어진 원시 신호로부터 신호 특징을 추출하고, 추출된 신호 특징을 분류 처리부(40)에 출력할 수 있다. 특징 추출부(30)는 컨벌루션 연산 및 맥스 풀링 연산에 의해 상기 원시 신호로부터 신호 특징을 추출할 수 있다. 특징 추출부(30)가 수행하는 컨벌루션 연산은 복수의 시간 간격을 갖는 확장된 컨벌루션 레이어들을 통해 수행될 수 있다.

[0043] 도 2는 본 발명의 일 실시예에 따른 멤버십 추출부(10)의 구성을 도시하는 개념도이다.

[0044] 멤버십 추출부(10)는 입력된 시계열 데이터로부터 잠재적인 멤버십을 계산한다. 잠재적인 멤버십( $h_{ij}$ )은 각 그래프 레이어에 대해 정점  $v_i$ 에서 정점  $v_j$ 로 향하는 간선의 존재 확률을 나타내고, 수학적식 5 및 수학적식 6에 의해 계산될 수 있다. 멤버십 추출부(10)는 정점-간선 연산 및 간선-정점 연산, 그리고 완전 연결(fully-connected) 네트워크를 사용한다.

$$h_i = f_3 \left( \sum_{i \neq j} f_2(f_1(\mathbf{x}_i) || f_1(\mathbf{x}_j)) \right) \quad (\text{수학적식 5})$$

$$h_{ij} = f_4 \left( \mathbf{h}_i || \mathbf{h}_j || f_2(f_1(\mathbf{x}_i) || f_1(\mathbf{x}_j)) \right) \quad (\text{수학적식 6})$$

[0047] 수학적식 5 및 수학적식 6에서  $||$  는 연결 연산(concatenation operation)을 나타낸다. f1 부터 f4까지는 지수적 선형 유닛(exponential linear unit: Djork-Arn v. Clevert, Thomas Unterthiner, and Sepp Hochreiter. Fast and accurate deep network learning by exponential linear units (ELUs). In Proceedings of the 3rd International Conference on Learning Representations, pages 1-14, 2015 참조)을 가지며, 배치 정규화



(batch normalization: Sergey Ioffe and Christian Szegedy. Batch normalization: accelerating deep network training by reducing internal covariate shift. In Proceedings of the 32nd International Conference on Machine Learning, pages 448-456, 2015 참조)를 갖는 완전 연결 네트워크이다.

도 3은 본 발명의 일 실시예에 따른 그래프 샘플링부(20)의 구성을 도시하는 개념도이다.

그래프 샘플링부(20)에서는 레이어 멤버십 정보로부터, 확률론적 또는 결정론적 샘플링을 통해 그래프 구조를 생성할 수 있다. 본 발명에서는 그래프 샘플링을 위해 확률론적 샘플링(Stochastic sampling, STO), 결정론적 이진화(DET: Deterministic Thresholding) 및 연속 샘플링(CON: Continuous sampling)의 3 가지 방법을 고려한다.

확률론적 샘플링 방법은 확률적으로 정점  $v_i$ 에서 정점  $v_j$ 까지의 잠재적 간선을 K 그래프 레이어 중 하나에 할당한다. 샘플링된 그래프 가중치는 불연속적이므로 Gumbel-softmax 재파라미터화 기술(문헌 28, 29 참조)이 사용되어 continuous relaxation을 제공하고 그래디언트 계산을 가능하게 한다.

$$\mathbf{z}_{ij} = \text{softmax}((\mathbf{h}_{ij} + \mathbf{q})/\tau) \quad (\text{수학식 7})$$

여기서,  $\mathbf{q} \in \mathbb{R}^K$  는 랜덤 벡터이고, 이 랜덤 벡터의 각 요소들은 IID(Independent and Identically Distributed) 속성을 갖고, 표준 Gumbel 분포를 따른다.  $\tau$  는 샘플링 평활도(smoothness)를 제어하는 소프트 맥스 온도이다. 본 실시예에서는 0.5로 설정하였다.  $v_i$ 로부터  $v_j$ 로의 비가중 간선( $w_{ij}^k$ )은 수학식 8에 의해 얻을 수 있다.

$$w_{ij}^k = \begin{cases} 1 & \text{if } k = \text{argmax}_l(z_{ij}^l) \\ 0 & \text{otherwise} \end{cases} \quad (\text{수학식 8})$$

추정된 그래프에는 복수의 그래프 레이어가 있으므로, 그래프 레이어마다 다른 유형의 연결성 정보가 모델링될 수 있다. 확률론적 샘플링 방법은 각 간선을 하나의 그래프 레이어에만 속하도록 제한하지만 결정론적 이진화 방법은 이 제한을 완화하여 한 쌍의 정점이 이진화를 통해 복수의 레이어에 간선을 갖게 한다.

$$w_{ij}^k = \begin{cases} 1 & \text{if sigmoid}(h_{ij}^k) > r \\ 0 & \text{otherwise} \end{cases} \quad (\text{수학식 9})$$

수학식 9에서  $r$ 은 임계값이고, 실시예에서 0.5로 설정하였다. 확률론적 샘플링 방법에 사용된 것과 동일한 continuous relaxation 기술을 사용하여 학습 동안에 불연속 변수를 차별화할 수 있다.

앞의 2가지 방법은 비가중 그래프를 구성하지만, 연속 샘플링 방법을 사용하면 간선 가중치를 연속적인 값으로 하여 다른 그래프 레이어에서 서로 다른 연결성 정도가 유지될 수 있다. 이를 위해, Gumbel-softmax 연산으로부터 얻어진 0과 1 사이의 연속적인 값을 갖는  $z_{ij}^k$  는 k 번째 그래프 계층에서  $v_i$ 에서  $v_j$ 까지의 간선 가중치로 직접 사용된다. 따라서 이 방법은 세 가지 방법 중 가장 일반적인 형태의 그래프 구조, 즉 가중치 및 방향성을 갖는 멀티 레이어 그래프를 생성한다.

특정한 정점 쌍 사이에는 직접적인 관계가 없을 수 있다. 이를 가능하게 하기 위해 그래프 레이어 중 하나를 스킵 레이어(Skip Layer)로 할당할 수 있다. 그래프가 분류 처리부(40)에 전달될 때 스킵 레이어는 폐기되므로, 이 레이어에 속하는 간선은 분류를 위해 사용되는 그래프에서 생략된다.

도 4는 본 발명의 일 실시예에 따른 특징 추출부(30)의 구성을 도시하는 개념도이다.

특징 추출부(30)는 1-D 컨벌루션 및 맥스 풀링 연산에 의해 원시 신호로부터 신호 특징을 추출할 수 있다. 신호의 동적 정보를 캡처하기 위해, 본 발명은 다양한 확장률(dilation rate)을 갖는 컨벌루션 레이어들을 포함하여

확장된 인셉션 모듈(inception module)의 1-D 버전을 채택한다. 낮은 확장률을 갖는 확장된 컨벌루션 레이어는 빠르게 변하는 고주파 정보에 해당하는 주변 샘플들 사이에 나타나는 특징을 포착하고, 높은 확장률을 갖는 확장된 컨벌루션 레이어는 큰 시간적 윈도우에 대하여 느리게 변화하는 특징을 포착한다.

$$U_i = [\mathbf{u}_{i1}, \dots, \mathbf{u}_{iT'}] \in \mathbb{R}^{T' \times F} \quad (\text{수학식 10})$$

신호 특징  $U_i$ 는 수학식 10에 의해 계산될 수 있다. 여기서,  $T'$ 는 감소된 신호 길이이고,  $F$ 는 특징 차원(feature dimension)이다.

도 5는 본 발명의 일 실시예에 따른 분류 처리부(40)의 구성을 도시하는 개념도이다.

분류 처리부(40)는 GNN(Graph Neural Network)를 포함하고, 신호 특징들과 구축된 그래프를 사용하여 분류를 수행하여 예측된 클래스 레이블  $\hat{y}$ 를 출력할 수 있다. 먼저, 신호 특징들에 대해 정점-간선 연산이 수행되고, 그 결과는 메시지 전달(message passing) 연산을 통해 그래프 구조와 결합되고 집계 연산(aggregation operation) 및 간선-정점 연산이 수행된다.

$$\mathbf{h}'_{it} = \sum_{i \neq j} \sum_{k=s}^K w_{ij}^k g_1^k(\mathbf{u}_{it} || \mathbf{u}_{jt}) \quad (\text{수학식 11})$$

수학식 11에서  $t$ 는 시간 인덱스이고, 스킵 레이어가 사용되는 경우에  $s=2$ 이고, 스킵 레이어가 사용되지 않는 경우에  $s=1$ 이다.  $g_1^k$ 는 입력 및 출력이 각각  $F$ -차원 및  $F'$ -차원, 즉  $\mathbf{h}'_{it} \in \mathbb{R}^{F'}$ 인 ReLU(Rectified Linear Unit)를 갖는 완전 연결된 네트워크에 의해 모델링된다. 마지막으로 이 결과는 스킵 커넥션을 통해 신호 특징들과 연결되어 벡터화 후에 완전 연결된 네트워크에 제공된다.

$$\hat{y} = g_2(\text{vec}(\{U_i\}_{i=1}^N) || \text{vec}(\{H'_i\}_{i=1}^N)) \quad (\text{수학식 12})$$

(여기서  $H'_i = [\mathbf{h}'_{i1}, \dots, \mathbf{h}'_{iT'}]$  이다.)

이하에서는 본 발명의 구체적인 실시예를 설명한다.

본 실시예에서는 인간의 정서적 정신 상태에 관한 가장 큰 데이터베이스 중 하나인 DEAP(Database for Emotion Analysis using Physiological Signals) 데이터 세트가 사용되었다. 실시예의 데이터 세트에는 40개의 비디오 자극을 시청하는 동안 32명의 피검자로부터 수집된 32 채널 EEG 기록 및 피검자에 의한 대응하는 감정 등급이 포함된다. 실시예에서는 딥 러닝 모델이 주어진 EEG 신호 세트를 40 개의 비디오 자극 중 하나로 분류하는 비디오 식별 작업을 수행하였다.

구체적으로, DEAP 데이터 세트의 1 분 길이의 각 EEG 신호는 2초 길이가 겹치는 3초 길이의 세그먼트로 분할된다( $T=384$ ). 그 결과, 총 74,240 개 (32개 피검자 $\times$ 40개 비디오 $\times$ 58개 세그먼트)의 32 채널 EEG 신호 세트가 얻어진다. 얻어진 신호 세트들은 전체 데이터 세트의 각각 80 %, 10 % 및 10 %를 보유하는 학습, 검증 및 테스트 데이터 세트로 무작위로 분리된다.

본 실시예의 딥러닝 모델은 PyTorch(Adam Paszke, Sam Gross, Soumith Chintala, Gregory Chanan, Edward Yang, Zachary DeVito, Zeming Lin, Alban Desmaison, Luca Antiga, and Adam Lerer. Automatic differentiation in PyTorch. In Proceedings of the NIPS 2017 Autodiff Workshop: The Future of Gradient-based Machine Learning Software and Techniques, pages 1-4, 2017 참조)로 구현되었고, Adam optimizer(Diederik P. Kingma and Jimmy Ba. Adam: a method for stochastic optimization. In Proceedings of the 3rd International Conference on Learning Representations, pages 1-15, 2015 참조)를 사용하여 학습되었다.

[0077] 모델 구조 및 학습 매개 변수에 대한 자세한 내용에 대하여 이하에서 설명한다.

[0078] 그래프 멤버십 추출:  $f_1$ ,  $f_2$  및  $f_3$ 은 256 개의 은닉 뉴런과 256 개의 출력 뉴런이 있는 완전 연결된 2 레이어 네트워크이다. 완전 연결된 각 레이어는 지수적 선형 유닛을 가지며, 배치 정규화가 출력 레이어에 사용된다.  $f_4$ 는 완전 연결된 3 개의 레이어를 포함한다. 3개의 레이어 중 처음의 2개의 레이어에는 지수적 선형 유닛을 갖는 256 개의 은닉 뉴런이 존재하고, 마지막 레이어에는 K개의 출력 뉴런이 존재한다.

[0079] 특징 추출: 각각의 확장된 인셉션 모듈은 각각 1, 2, 4 및 8의 확장률을 갖는, 커널 크기가 3 인 4 개의 1-D 컨볼루션 층으로 구성된다. 각 계층에는 8 개의 출력 채널이 있으므로  $F = 8 \times 4 = 32$ 이다. 최대 풀링 크기는  $\alpha = 4$ 로 설정된다. 신호 확장의 길이가  $T' = 6$ 이 되도록 3 개의 확장된 시작 모듈이 일렬로 연결된다.

[0080] 신경망 그래프:  $g_1^k$  ( $k = 1, 2, K$ )는 256 개의 은닉 뉴런과 ReLU를 갖는 256 개의 출력 뉴런을 갖춘 2 레이어의 완전 연결 네트워크이다.  $g_2$ 는 ReLU(Rectified Linear Unit)를 갖는 256 개의 은닉 뉴런과 40 개의 소프트 맥스 출력 뉴런을 갖는 2 레이어의 완전 연결 네트워크이다.

[0081] 학습: 본 발명의 실시예에 따른 딥 러닝 모델은 교차 엔트로피 손실을 최소화하는 것을 목적으로 30 에포크(epoch) 동안 0.0001의 학습률(learning rate)로 Adam 옵티마이저(Diederik P. Kingma and Jimmy Ba, Adam: a method for stochastic optimization. In Proceedings of the 3rd International Conference on Learning Representations, pages 1-15, 2015 참조)를 사용하여 학습되었다. 배치(batch) 크기는 32이다. 훈련 절차는 하나의 NVIDIA K80 GPU를 사용하여 약 10-12 시간이 걸렸다. 테스트 정확도는 훈련 과정 중 최상의 검증 정확도를 나타낸 네트워크를 사용하여 측정되었다. 다른 무작위 시드로 실험을 5 회 반복하고 평균 성능을 측정하였다.

[0083] [표 1]

|          | k-NN   | Random forest | ChebNet | GNN only | 본 발명          |
|----------|--------|---------------|---------|----------|---------------|
| Accuracy | 48.50% | 51.34%        | 65.27%  | 44.70%   | <b>91.23%</b> |

[0084]

[0085] 상기 [표 1]은 본 발명의 일 실시예에 따른 딥 러닝 모델(그래프 샘플링을 위한 결정론적 이진화 방법과 스킵 레이어가 없는 3 개의 그래프 레이어 사용)과 기존 방법의 분류 정확도를 나타낸다. k-NN(k-nearest neighbor)과 랜덤 포레스트(Random Forest)를 포함한 전통적인 분류기, 그래프 구조가 전극 사이의 물리적 거리에 의해 결정되고 신호 엔트로피가 특징으로 사용되는 ChebNet 기반 방법(Soobeom Jang, Seong-Eun Moon, and Jong-Seok Lee. EEG-based video identification using graph signal modeling and graph convolutional neural network. In Proceedings of the 2018 IEEE International Conference on Acoustics, Speech and Signal Processing, pages 3066-3070, 2018 참조)을 테스트하였다. 또한, 일 실시예에 따른 딥 러닝 모델에서 그래프 구조 추출을 제외한 모델(표 1에서 "GNN only"로 표시함)도 테스트하였다. 표 1로부터 본 발명의 일 실시예에 따른 딥 러닝 모델이 다른 방법보다 성능이 훨씬 뛰어나다는 것이 명확히 파악된다. 본 발명의 딥 러닝 모델은 ChebNet 기반 방법보다 성능이 뛰어나며, 이것은 데이터 중심의 그래프 및 기능 추출이 효과적이라는 것을 나타낸다. 또한, 본 발명의 딥 러닝 모델에서 그래프 추출을 생략하면(즉, "GNN only"의 경우) 성능이 크게 저하되는 것으로부터, 그래프 구조가 EEG 데이터 모델링에 중요하다는 것을 파악할 수 있다.

[0086] [표 2]

| #Layers (K) | 1+skip | 2      | 2+skip | 3             | 3+skip        |
|-------------|--------|--------|--------|---------------|---------------|
| STO         | 69.28% | 73.98% | 76.03% | 86.86%        | 86.65%        |
| DET         | 55.91% | 86.61% | 83.14% | <b>91.23%</b> | <b>91.04%</b> |
| CON         | 58.31% | 76.29% | 77.84% | <b>90.08%</b> | 89.43%        |

[0087]

[0088] 상기 [표 2]에서는 그래프 샘플링 방법, 그래프 레이어 수(K) 및 스킵 레이어 유무의 다양한 조합에 대한 모델의 정확도를 나타낸다. 결과는 그래프 레이어의 수가 가장 중요한 매개 변수임을 보여준다. 대부분의 기존 연구에서 고려된 단일 계층 그래프로는 충분하지 않으며 분리된 그래프 계층들과 다른 유형의 영역 간 상호 작용을

모델링하는 것이 매우 유리하다. 3 종류의 그래프 샘플링 방법 중 결정론적 이진화 방법은  $K=1$  인 경우를 제외하고 최상의 성능을 나타내고, 연속 샘플링 방법은 그래프 레이어 수가 많을 때 우수한 성능을 나타내었다. 확률론적 샘플링 방법에서는 그래프 레이어 중 하나의 간선만 선택하는 것에 의해 성능이 제한되는 것으로 파악되었다. 스킵 레이어의 존재는 특히 그래프 레이어 수가 많은 경우 성능에 미세한 영향만 미친다.

[0090]

도 6a 내지 도 6d는 본 발명의 일 실시예에 따른 원시 신호 및 추출된 그래프를 도시한다.

[0091]

도 6a는 피검자 #1에 대한 원시 신호를 시각화한 것이고, 도 6b는 피검자 #1에 대한 추출된 그래프이다. 도 6c는 피검자 #2에 대한 원시 신호를 시각화한 것이고, 도 6d는 피검자 #2에 대한 추출된 그래프이다. 다른 색상은 다른 클래스를 나타낸다. 도 2b 및 도 2d의 플롯은 더 좋은 시각화를 위해 적색 박스로 표시된 영역의 확대 버전이다.

[0092]

추출된 그래프 구조는 t-SNE 기법(Laurens van der Maaten and Geoffrey Hinton. Visualizing data using t-SNE. Journal of Machine Learning Research, 9:2579-2605, 2008 참조)을 사용하여 분석되었다. 도 6a 내지 도 6d는 2개의 피검자에 대해 추출된 그래프에서 원본 EEG 신호의 t-SNE 시각화와 모든 그래프 레이어의 인접 행렬들을 비교한다. 여기서 다른 색상은 다른 클래스를 나타낸다. 도 6a와 도 6c에서 서로 다른 클래스의 원시 신호는 혼합되어 있으므로 구분하기가 쉽지 않다. 한편, 도 6b와 도 6d에서는 동일한 클래스의 그래프는 밀접하게 그룹화되며, 이것은 분류에 크게 기여한다.

[0094]

그래프 구조에 대한 근거가 없기 때문에 추출된 그래프의 정확성의 평가가 어렵다. 이에 따라, 추출된 그래프의 품질을 평가하기 위한 하나의 방법으로서, 반복 실험에 대한 일관성을 테스트하였다. 즉, 상이한 반복 실험으로부터 획득된 그래프 구조들 간의 모든 페어 단위 조합에 대해 비유사성이 측정된다. 획득된 그래프 구조들 간의 낮은 수준의 비유사성, 즉 높은 수준의 일관성은 신뢰할 수 있고 의미가 있음을 나타낸다. 두 그래프 구조의 비유사성을 계산하는 전체 절차는 [알고리즘 1]에 요약되어 있다. [알고리즘 1]에서, 거리 함수(Dist)는 두 그래프 레이어의 인접 행렬을 입력으로 하여 그 거리를 계산하는 함수이며, 실시예에서는 절대 차이의 합을 채택하였다. 정점은 구별된 EEG 전극으로 명확하게 식별되어 차이를 계산할 수 있기 때문에 동형 이성(isomorphism)의 문제는 없다. 모든 반복 쌍에서 계산된 거리들의 평균값을 가능한 간선의 총 수로 나누고, 1로부터 감산하여 최종적인 일관성 스코어를 얻었다.

[0095]

[알고리즘 1]

---

**Algorithm 1** Computing graph dissimilarity

---

**Input:**  $Dist(\cdot, \cdot), W_{(m)} \in \mathbb{R}^{K \times |E|}, W_{(n)} \in \mathbb{R}^{K \times |E|}$

**Output:**  $D^*, P^*$

```

1:  $M = \text{GetPerm}(1, \dots, K)$                                 ▷ Make a set of permutations in the lexicographic order
2:  $P^* \leftarrow (1, \dots, K), D^* \leftarrow \infty$                 ▷ Initial permutation and distance
3: for  $P$  in  $M$  do                                              ▷ Pick a permutation of  $(1, \dots, K)$ 
4:    $W'_{(m)} \leftarrow \text{Permute}(W_{(m)}, P)$                     ▷ Permute the graph layers in  $W_{(m)}$  with  $P$ 
5:    $D = \text{Dist}(W'_{(m)}, W_{(n)})$ 
6:   if  $D < D^*$  then
7:      $D^* \leftarrow D$ 
8:      $P^* \leftarrow P$ 
9:   end if
10: end for

```

---

[0096]



[0097] [표 3]

| #Layers ( $K$ ) | 1+skip | 2      | 2+skip | 3      | 3+skip |
|-----------------|--------|--------|--------|--------|--------|
| STO             | 43.91% | 89.32% | 89.67% | 83.41% | 79.10% |
| DET             | 61.23% | 88.01% | 85.31% | 77.79% | 77.66% |
| CON             | 55.87% | 84.01% | 76.58% | 81.64% | 82.11% |

[0098]

[0099]

상기 [표 3]은 일관성 분석 결과를 백분율로 나타낸다.  $K=1$  인 경우를 제외하고, 다른 조건에서 높은 일관성 수준(약 75 ~ 90 %)이 관찰된다. 이는 그래프 추출 프로세스가 안정적으로 작동함을 나타내고, 추출된 그래프에 의미있는 데이터 표현이 포함되어 있는 것으로 예상할 수 있다.

[0101]

도 7은 본 발명에서 사용된 그래프 표현을 위한 32개의 EEG 전극의 명칭 및 위치를 도시하는 그래프이다. 후술하는 그래프 구조의 예는 도 7에 도시된 32개의 EEG 전극에 기초한 것이다.

[0103]

도 8a 내지 도 8c는 본 발명의 일 실시예에 따라 얻어진 그래프 구조의 예를 도시하는 그래프이다.

[0104]

본 발명의 실시예 중 가장 좋은 결과가 나온 실시예의 경우(즉,  $K=3$ , 스킵 레이어 없음, 결정론적 이진화)에 대하여, 감정적 인지 반응의 관점에서 학습된 표현을 이해하기 위해 획득된 그래프 구조를 조사하였다. 획득된 그래프 구조는 각 반복마다 다르므로, 반복 실험에서 얻어진 여러 그래프 중 가장 자주 나타나는(상위 10%) 간선을 포함하는 대표 그래프 구조를 얻었다. 도 8a는 모든 비디오 자극에 걸쳐 가장 자주 활성화되는 간선을 포함하는 대표 그래프이다. 도 8b와 도 8c는 각각 가장 높은 유인가(valence)를 가지는 비디오 자극과, 가장 낮은 유인가를 가지는 비디오 자극에 대한 대표적인 그래프 구조에 대응한다. 정점의 크기는 입력 차수(in-degree)를 나타낸다. 출력 차수(out-degree)는 모든 정점에서 유사하므로 표시를 생략한다.

[0105]

도 8a의 제 1 레이어(적색)에서, 좌측 측두엽을 향한 강한 활성화가 관찰된다. 측두엽은 장면과 같은 복잡한 시각 자극의 처리와 관련이 있다. 정서적 처리에 중요한 역할을 하는 편도체(amygdala)도 내측 측두엽에 위치한다. 따라서, 제 1 레이어는 정서적 시각 자극에 노출된 정신 상태를 나타낸다. 제 1 레이어에서 시각 키텐즈 및 감정 처리와 관련된 기능적 연결성은 도 8b 및 8c에서도 관찰된다. 도 8c의 제 1 레이어는 각각 정서적 처리와 시각 자극의 감각 처리와 관련된 전두엽과 후두엽으로 들어가는 많은 수의 간선들을 포함한다. 도 8b의 제 1 레이어의 경우, 연결성은 비디오 자극의 내용과 크게 관련되어 있다. 이 비디오에는 리듬 댄스가 포함되어 있는데, 이것은 아마도 움직임 관련 인식에 관여하는 것으로 알려진 전두 중양 영역으로 들어오는 연결에 기여하는 것으로 이해된다.

[0106]

도 8b 및 8c의 제 2 레이어(녹색)는 서로 명확하게 구별되는 패턴을 도시한다. 도 8b에서 정면 영역의 오른쪽 부분은 왼쪽 부분보다 많은 수의 들어오는 연결을 수신하고, 이것은 도 8c와 반대이다. 기존 관련 연구 논문들에서, 우측 및 좌측 전두엽의 비대칭이 유인가와 크게 관련되어 있다고 지속적으로 보고되었다. 즉, 전뇌의 일측은 정서적 처리 과정에서 타측에 비해 더 활성화되고, 더 활성화된 쪽은 감정의 극성에 따라 변화하며, 이는 도 8b와 도 8c의 제 2 레이어의 관찰된 패턴과 일치한다. 도 8a의 제 2 레이어에서는 들어오는 간선들이 뇌 전체에 걸쳐 퍼져 있으며, 이는 긍정적 및 부정적 유인가 비디오 자극에 나타나는 패턴의 집계 결과로 생각된다. 따라서, 제 2 레이어가 뇌 신호가 가지는 정서적 특성을 학습했다고 추론될 수 있다.

[0107]

도 8a 내지 도 8c의 제 3 레이어(청색)는 상대적으로 적은 연결을 나타내고, 주로 다른 계층을 보완하는 것으로 보인다. 모든 경우에, 뇌의 정면 영역은 많은 수의 연결을 수신한다. 전두엽에는 도 8b에 여러 개의 들어오는 간선들이 존재하는데, 이것은 제 1 레이어(즉, 움직임 관련)의 경우와 같은 이유 때문인 것으로 생각된다.

[0109]

도 9는 본 발명의 일 실시예에 따른 연결성 학습 방법을 나타내는 흐름도이다.

[0110]

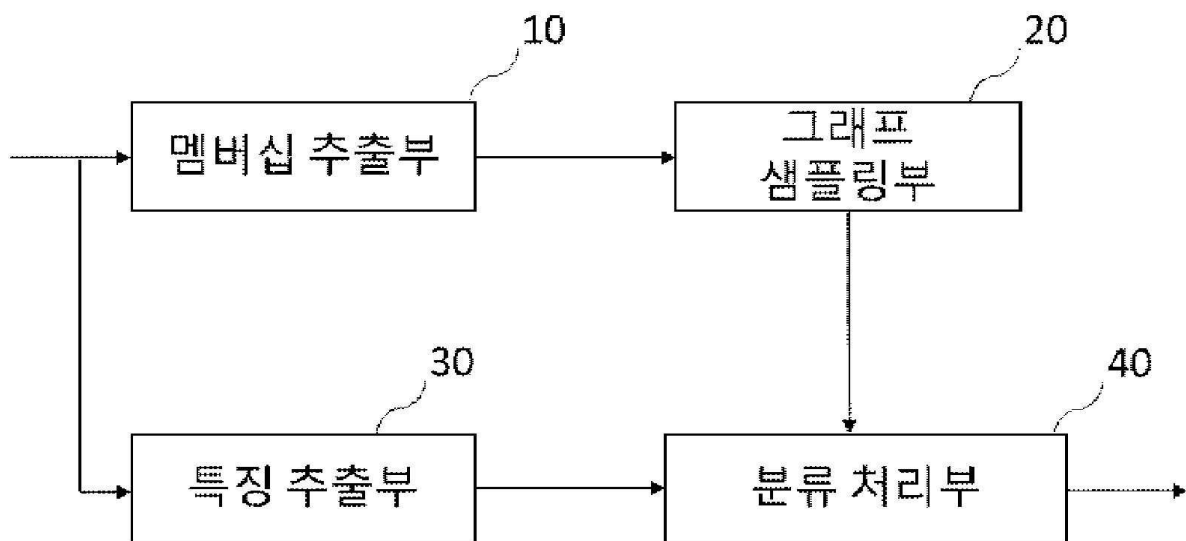
도 9를 참조하면 본 발명의 일 실시예에 따른 연결성 학습 방법은 멤버십 추출 단계(S10), 그래프 샘플링 단계(S20), 특징 추출 단계(S30) 및 분류 처리 단계(S40)를 포함할 수 있다.

[0111] 멤버십 추출 단계(S10), 그래프 샘플링 단계(S20), 특징 추출 단계(S30) 및 분류 처리 단계(S40)는 도 1을 참조하여 설명한 연결성 학습 장치(1)의 멤버십 추출부(10), 그래프 샘플링부(20), 특징 추출부(30) 및 분류 처리부(40)에 의해 각각 수행될 수 있으며, 멤버십 추출 단계(S10), 그래프 샘플링 단계(S20), 특징 추출 단계(S30) 및 분류 처리 단계(S40)에 대한 설명은 멤버십 추출부(10), 그래프 샘플링부(20), 특징 추출부(30) 및 분류 처리부(40)에 대한 설명이 참조될 수 있다.

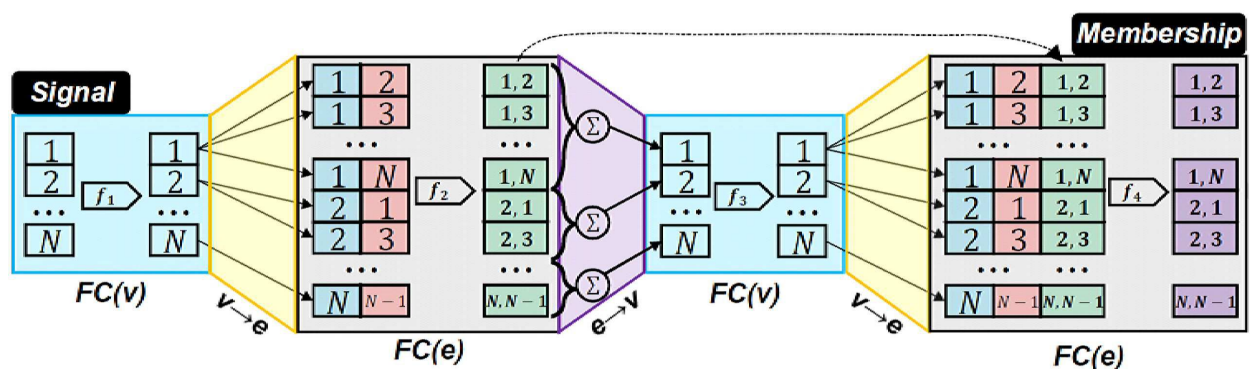
[0113] 이상에서 설명한 본 발명이 전술한 실시예 및 첨부된 도면에 한정되지 않으며, 본 발명의 기술적 사상을 벗어나지 않는 범위 내에서 여러가지 치환, 변형 및 변경이 가능하다는 것은, 본 발명이 속하는 기술분야에서 통상의 지식을 가진 자에게 있어 명백할 것이다.

## 도면


### 도면1



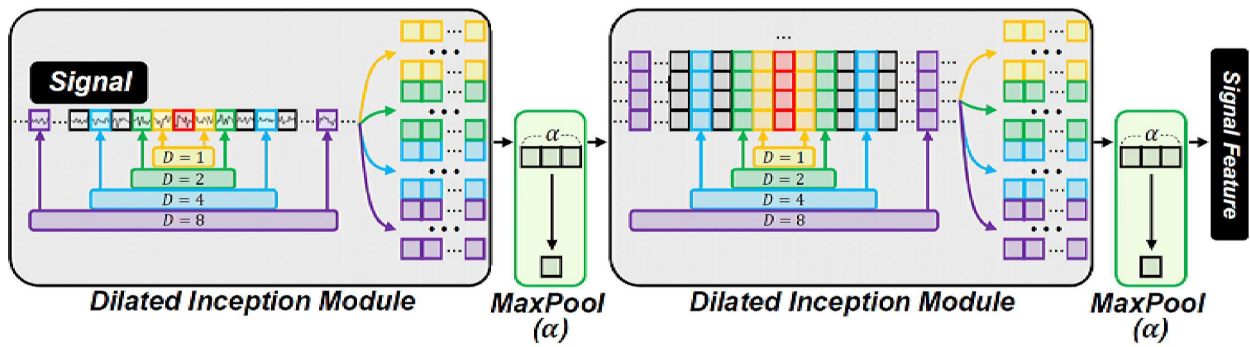
### 도면2



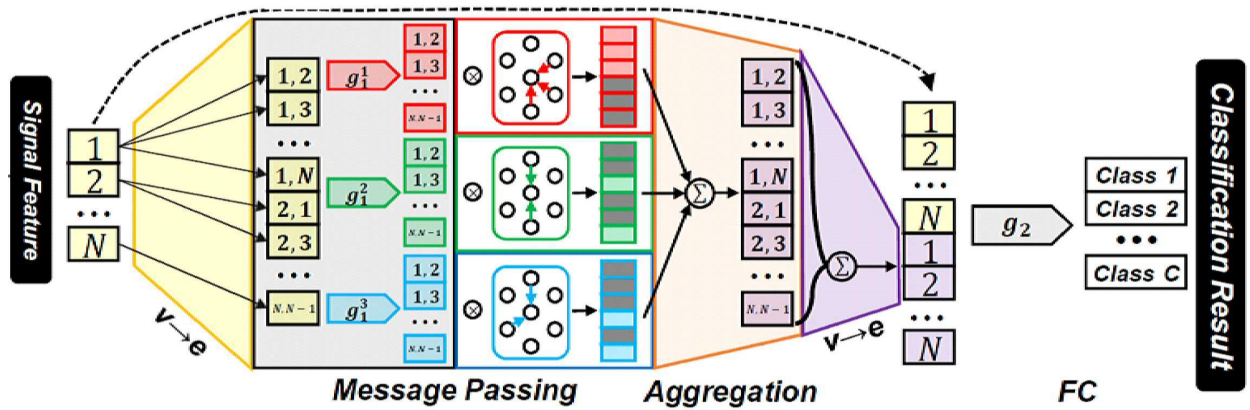
도면3



도면4




도면5







도면6a




도면6b




도면6c




도면6d




도면7




도면8a



도면8b



도면8c



도면9

